

BAB I PENDAHULUAN

1.1 Latar Belakang

Tidak ada satu metode peramalan yang paling sempurna atau terbaik yang dapat dipakai untuk semua jenis data yang dimiliki. Hal tersebut merupakan hal yang harus diingat dalam melakukan peramalan. Suatu metode peramalan mungkin cocok untuk membuat ramalan mengenai suatu kasus tertentu tetapi belum tentu cocok untuk membuat ramalan untuk kasus yang lain (Satyarini, 2007). Dalam menentukan atau memilih metode peramalan yang paling tepat, terlebih dahulu harus dikenali pola data yang menirukannya dan karakteristik data yang ada, sehingga dapat menentukan atau memilih teknik peramalan yang tepat untuk data tersebut. Informasi mengenai pola dan karakteristik data perlu diketahui, karena pada proses peramalan hal yang akan dilakukan yaitu memproyeksikan data masa lalu ke masa depan. Pola yang terjadi pada data masa lalu akan sangat berpengaruh pada nilai data yang akan diramalkan pada masa yang akan datang (Satyarini, 2007).

Menurut Caraka (2016) dalam buku Makridakis (1999), peramalan adalah suatu kegiatan memperkirakan apa yang terjadi pada masa yang akan datang berdasarkan nilai sekarang dan masa lalu dari suatu peubah. Metode peramalan yang digunakan berdasarkan sejarah data masa lalu dikenal dengan sebutan metode runtun waktu (*time series*). Metode runtun waktu adalah metode meramalkan masa yang akan datang dengan menggunakan data masa lalu yang didekomposisi (Satyarini, 2007). Metode analisis runtun waktu merupakan salah satu prosedur statistika yang diterapkan untuk meramalkan struktur probabilitas keadaan yang akan datang dalam rangka pengambilan keputusan (Makridakis, Wheelwright, & McGee., 1999). Dalam Kustiara (2019), perkembangan teknik peramalan menggunakan analisis runtun waktu seperti metodologi Box-Jenkins dimulai semenjak tahun 1976 oleh George E.P.Box dan Gwilym M.Jenkins yang merupakan tokoh pertama yang mengenalkan analisis runtun waktu. Menurut Box dan Jenkins, *time series* merupakan pengamatan sekarang tergantung pada satu atau

beberapa pengamatan sebelumnya. Perkembangan teknik peramalan analisis runtun waktu ini berawal dari metode *Autoregressive* (AR), *Moving Average* (MA), yang kemudian berkembang menjadi *Autoregressive Moving Average* (ARMA) dan metode *Box-Jenkins* (ARIMA).

Menurut Makridakis (1999), *Autoregressive* merupakan suatu bentuk regresi yang menghubungkan dengan dirinya sendiri (nilai-nilai sebelumnya pada *time lag* (selang waktu) yang bermacam-macam). Jadi suatu metode *Autoregressive* akan menyatakan suatu ramalan sebagai fungsi nilai-nilai sebelumnya dari *time series* tertentu (Umam, 2016). Sedangkan *Moving Average* (rata-rata bergerak) adalah metode peramalan perataan nilai dengan mengambil sekelompok nilai pengamatan yang kemudian dicari rata-ratanya, lalu menggunakan rata-rata tersebut sebagai ramalan untuk periode. Istilah rata-rata bergerak digunakan, karena setiap kali data observasi baru tersedia, maka angka rata-rata yang baru dihitung dan dipergunakan sebagai ramalan (Rahayu, 2016). Model ARMA (p,q) adalah model campuran yang merupakan perluasan dari model *Autoregressive* (AR (p)) dan model *Moving Average* (MA (q)). Model AR (*Autoregressive*), MA (*Moving Average*), dan ARMA (*Autoregressive Moving Average*) merupakan model *time series* yang stasioner. Sedangkan model *time series* nonstasioner yaitu model ARIMA (Soejoeti, 1987).

Autoregressive Integrated Moving Average (ARIMA) merupakan salah satu model peramalan berbasis *time series* (runtun waktu) yang dikembangkan oleh Box dan Jenkins (1976). ARIMA sangat efektif digunakan untuk memodelkan data yang tidak stasioner, yang ditunjukkan oleh plot *Autocorrelation Function* (ACF) yang turun secara eksponensial atau membentuk gelombang sinus. Beberapa data yang tidak stasioner dan plot *Autocorrelation Function* (ACF)-nya tidak turun secara eksponensial melainkan secara lambat atau hiperbolik dikategorikan sebagai data runtun waktu *long memory* (memori jangka panjang) (Paridi, 2019). *Long memory* merupakan salah satu fenomena dalam *time series* yang merupakan kondisi dimana setiap observasi memiliki korelasi yang cukup kuat dengan observasi lainnya meskipun jarak waktu antar observasi cukup jauh (Kartikasari, 2020). Hosking (1981) telah memperkenalkan metode *Autoregressive Fractionally Integrated Moving Average* (ARFIMA) untuk meramalkan data memori jangka panjang.

Metode ARIMA hanya dapat menjelaskan data runtun waktu jangka pendek (*short memory*) sedangkan metode ARFIMA dapat menjelaskan data runtun waktu baik jangka pendek maupun jangka panjang (Ningrum, 2009). Menurut penelitian yang dilakukan Caraka, dkk. (2016), menyimpulkan bahwa, ARFIMA diakui dapat mengatasi kelemahan metode ARIMA sehingga dapat diterapkan pada kajian data *temperature* khususnya di kabupaten Karimun Kepulauan Riau. Dengan mengambil nilai AIC yang terkecil, cocok untuk memprediksi *temperature* di Karimun, Kepulauan Riau.

Kasus yang memiliki kecenderungan bersifat *long memory* salah satunya adalah pada data harga saham (Kartikasari, 2020). Salah satu saham emiten perbankan yang paling aktif ditransaksikan secara nilai adalah saham PT Bank Rakyat Indonesia yaitu terdapat sebanyak 122.112.351.900 saham (id.investasi.com). Sedangkan saham yang lain masih jauh dibawah saham PT. BRI. Akan tetapi tidak menutup kemungkinan bahwa saham PT. BRI mengalami kenaikan dan penurunan di setiap waktu. Fenomena tersebut salah satunya dapat dideteksi sebagai kejadian yang mengikuti proses *long memory*.

Berinvestasi dalam saham memilki resiko besar tetapi kalau untung juga menggiurkan karena dalam pasar keuangan dikenal istilah *high risk high return*, *low risk low return*. Dengan demikian kalau investor ingin berinvestasi maka harus memahami pergerakan harga saham melalui pergerakan dari indeks harga. Indeks harga saham berubah setiap hari karena perubahan harga pasar yang terjadi setiap hari dan adanya saham tambahan. Perubahan harga saham individu di pasar terjadi karena perubahan permintaan dan penawaran baik karena faktor yang rasional maupun yang irrasional. Faktor yang sifatnya rasional mencakup kinerja perusahaan, tingkat bunga, tingkat inflasi, tingkat pertumbuhan, kurs valuta asing atau indeks harga saham negara lain, sedangkan faktor irrasional mencakup rumor di pasar, mengikuti mimpi, bisikan teman atau permainan harga (Kartika, 2010). Oleh karena itu, investor harus hati-hati terhadap pergerakan harga saham yang terlalu cepat naik atau terlalu cepat turun dengan tajam atau istilahnya terjadinya volatilitas harga saham. Volatilitas merupakan metode statistik untuk mengukur fluktuasi harga selama periode tertentu, namun bukan untuk mengukur tingkat harga, melainkan mengukur tingkat variasinya selama periode tertentu (Carolina,

2016). Kemampuan investor untuk memprediksi ada tidaknya volatilitas harga saham akan mempengaruhi *return* yang akan didapat investor. Adanya volatilitas akan menyebabkan resiko dan ketidakpastian yang dihadapi investor semakin besar sehingga minat investor untuk berinvestasi menjadi tidak stabil. Menurut Peng (2001), tujuan utama dari investasi dalam bentuk saham adalah untuk memaksimalkan *return* dan meminimalkan risiko yang didapatkan dari *return*. *Return* saham dapat berupa laba perusahaan yang dibagikan (*dividen*) atau hasil jual beli saham (*capital gain*), namun harga jual dapat berbeda dari harga belinya sehingga ada potensi keuntungan dan kerugian dari transaksi jual-beli saham (Zubir, 2013). Sehingga investasi pada saham memerlukan analisis yang mendalam agar investor mengetahui kapan harus menjual atau membeli saham tertentu sehingga dapat meningkatkan keuntungan, salah satu caranya yaitu dengan meramalkan harga saham yang akan datang. Ketersediaan data harga saham dari waktu ke waktu pada Bursa Efek dapat dimanfaatkan untuk melakukan analisis teknis sehingga harga saham yang akan datang bisa diramalkan untuk meningkatkan keuntungan investor (Rusmalawati, 2018).

Peramalan merupakan salah satu input penting bagi para manajer dalam pengambilan keputusan investasi. Berinvestasi didalam saham dihadapkan dengan risiko yang tinggi karena harga saham bersifat fluktuatif dan stokastik. Oleh karena itu, dibutuhkan pemodelan harga saham yang tepat agar peramalannya mendekati harga saham aktual (Irawan, 2015). Ketidakpastian yang dihadapi data harga saham biasanya mengakibatkan terjadinya pengelompokan volatilitas (*volatility clustering*) yaitu berkumpulnya sejumlah *error* dengan besar yang relatif sama dalam beberapa waktu yang berdekatan. Volatilitas digunakan untuk menggambarkan fluktuasi dari suatu data, sehingga memungkinkan datanya bersifat heteroskedastisitas. Dengan kondisi tersebut diperlukan suatu teknik untuk menangani data yang terindikasi adanya heteroskedastisitas. Jika data tersebut mengalami heteroskedastisitas, maka pemodelan dengan teknik ARFIMA akan menjadi lebih akurat apabila varian *error*-nya juga dilihat pergerakannya dari waktu ke waktu (Mutiara, 2016).

Berdasarkan sifat variansi residualnya, metode runtun waktu dibagi menjadi dua yaitu runtun waktu homoskedastis dan heteroskedastis. Homoskedastisitas

merupakan data yang variansi residualnya konstan sedangkan heteroskedastisitas sebaliknya. Homoskedastisitas yang ada pada data runtun waktu dapat dimodelkan dengan model *Box Jenkins* yaitu model *Autoregressive* (AR), *Moving Average* (MA), *Autoregressive Moving Average* (ARMA), dan *Autoregressive Integrated Moving Average* (ARIMA) (Cryer, 2008). Sedangkan heteroskedastisitas yang ada pada data runtun waktu dapat dimodelkan dengan menggunakan model *Autoregressive Conditional Heteroskedasticity* (ARCH) (Engle, 1982). Model Engle ini merupakan model yang digunakan untuk memodelkan data yang memiliki variansi yang tidak konstan atau heteroskedastisitas dengan melihat hubungan variansi bersyarat dari kombinasi linear kuadrat di masa lalu (Tsay, 2002). Namun, pada data finansial dengan tingkat volatilitas yang besar, model ARCH memerlukan orde yang sangat besar pula. Maka Bollerslev (1986) mengembangkan model ARCH menjadi *Generalized ARCH* (GARCH). Model GARCH merupakan model yang varian residualnya tidak hanya dipengaruhi oleh residual periode lalu, tetapi juga varian residual periode lalu (Tsay, 2002). Jika data tersebut mengalami heteroskedastisitas, maka pemodelan dengan teknik ARFIMA akan menjadi lebih akurat apabila varian *error*-nya juga dilihat pergerakannya dari waktu ke waktu (Mutiara, 2016).

Model GARCH masih memiliki kekurangan, yaitu tidak dapat mengatasi pengaruh asimetrik (*leverage effect*). *Leverage effect* yaitu suatu keadaan *bad news* dan *good news* yang memberikan pengaruh asimetris terhadap volatilitas (Chen, 2005). Keadaan dikatakan *bad news* ketika volatilitas mengalami penurunan sedangkan keadaan dikatakan *good news* ketika volatilitas mengalami kenaikan secara berkala. Selain itu, model GARCH membatasi nilai parameternya agar variansi bersyaratnya tidak negatif, serta terlalu berlebihan dalam memprediksi nilai volatilitasnya. Karena kekurangan tersebut, model GARCH dikembangkan kembali pada tahun 2010 oleh Francq dan Zakoian menjadi model *Integrated Generalized Autoregressive Conditional Heteroskedasticity* (IGARCH) yang dapat menutupi kelemahan model GARCH.

Salah satu modifikasi dari model IGARCH adalah FIGARCH. Menurut Jondeau (2007), model *Fractionally Integrated Generalized Autoregressive Conditional Heteroskedasticity* (FIGARCH) secara empiris merupakan model

volatilitas *long memory* dalam pasar finansial. Untuk menunjukkan sifat-sifat volatilitas *long memory* dalam pasar finansial, Baillie, Bollerslev & Mikkelsen pada tahun 1996 memperluas model IGARCH dengan mengganti operator diferensi pertama dan dikembangkan model FIGARCH. Keutuhan varian bersyarat yang disiratkan dalam model IGARCH tampak terlalu membatasi dan tampaknya bertentangan dengan bukti empiris. Terlihat bahwa model GARCH dan IGARCH memiliki memori yang jauh lebih pendek dari pada seri keuangan umumnya. Proses FIGARCH memberikan fleksibilitas tambahan yang bertujuan menangkap efek *long memory* dalam volatilitas. Proses FIGARCH menunjukkan peluruhan hiperbolik ACF.

Menurut Tsay (2002), kelemahan model ARCH/ GARCH tersebut juga bisa diperbaiki dengan menggunakan model GARCH asimetris lainnya, seperti model *Asymmetric Power ARCH* (APARCH). Model APARCH adalah model yang mampu menangkap kejadian ketidakasimetrisan *good news* dan *bad news* dalam volatilitas dengan menyatakan koefisien *asymmetric* untuk mengatasi *leverage effect* dalam perhitungan (Sidadadolog, 2020). Model APARCH juga dapat dimodifikasi menjadi model FIAPARCH. Tse (1998) mengusulkan model APARCH (FIAPARCH) yang terintegrasi secara fraksional, yang memperluas model FIGARCH dengan menambahkan fungsi $(|\varepsilon_i| - \gamma_i \varepsilon_i)^\delta$ dari model APARCH untuk menangkap asimetri dan properti memori-panjang dalam varian bersyarat. Dimana ε_i merupakan *error* dari model ARMA(p,q).

ARFIMA-FIAPARCH merupakan model *time series* yang mampu menangkap memori panjang dan asimetri dalam varians bersyarat dan kekuasaan mentransformasi proses varians bersyarat pada indeks volatilitas (Sriboonchitta, 2010). Balibey & Turkyilmaz juga mengungkapkan bahwa model FIAPARCH memiliki hasil yang lebih akurat dalam menangkap fakta bergaya dalam volatilitas Pasar Saham Turki. Dimana modifikasi dari model ARCH ini dikembangkan dan diterapkan pada model ARMA untuk mengoreksi asumsi kontradiksi data ekonomi deret waktu, khususnya data yang memiliki varians tinggi dengan varian non-stasioner dan *error*-nya (Enders, 2004).

Model ARMA (p,q) dapat ditulis sebagai berikut.

$$\phi(B)Y_t = \theta(B)\varepsilon_t, t = 1, 2, 3, \dots, T$$

dimana

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$$

$$\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_p B^p$$

$\{Y_t\}_{t=1}^T$ merupakan kumpulan observasi dari proses yang diamati, dan

$\{\varepsilon_t\}_{t=1}^T$ merupakan deret kesalahan stasioner.

Model ARCH (p) dapat ditulis sebagai berikut.

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 \text{ atau } \sigma_t^2 = \omega + \alpha(B)\varepsilon_t^2$$

dimana

$$\alpha(B) = \alpha_1 B + \alpha_2 B^2 + \dots + \alpha_p B^p$$

Sehingga investor cukup fokus pada varians bersyarat seperti prediksi *return* dan varians. Sedangkan ARMA menunjukkan nilai *mean* dan varians secara bersamaan (Engle, 1982). GARCH dikembangkan dari ARCH untuk menyesuaikan varians yang akan dicirikan sebagai proses ARMA yaitu diterapkan dalam model varian waktu di pasar uang (Engle, 1982; Bollerslev, 1986). Baillie, Bollerslev, dan Mikkelsen (1996) mengusulkan model FIGARCH yang secara efektif menangkap pengelompokan volatilitas dan memori panjang karena model GARCH menunjukkan memori pendek dan tidak dapat menganalisis memori hiperbolik dalam proses volatilitas bersyarat dan menangkap asimetri dalam volatilitas pasar ekuitas. Dengan temuan sebelumnya dari Ding, Granger, dan Engle (1993) dan Baillie, dkk. (1996) yang menyarankan pemodelan varian bersyarat dari data keuangan frekuensi tinggi dengan menggunakan model APARCH atau FIGARCH. Tse (1998) mengembangkan *Fractionally Integrated Model Asymmetric Power* ARCH yaitu FIAPARCH, yang memungkinkan memori lama dan asimetri dalam volatilitas (Sriboonchitta, 2010).

Pada tahun 2017, Malinda melakukan penelitian yang membandingkan performa peramalan dari beberapa model, diantaranya ARFIMA, ARFIMA-FIGARCH, ARFIMA-*Fractionally Integrated Asymmetric Power Autoregressive Conditional Heteroskedasticity* (ARFIMA-FIAPARCH) dan ARFIMA-*Hyperbolic Generalized Autoregressive Conditional Heteroskedasticity* (ARFIMA-HYGARCH) pada *return* harga penutupan untuk ETF ASEAN. Penelitian tersebut menghasilkan performa peramalan Model ARFIMA-FIAPARCH yang berkinerja lebih baik untuk menyelidiki memori panjang dalam volatilitas dan volatilitas asimetris untuk ETF ASEAN. Oleh karena itu, model ARFIMA-FIAPARCH dipilih untuk memodelkan data *return* harga penutupan untuk ETF ASEAN karena mampu mengatasi heteroskedastisitas, memperbolehkan adanya respon volatilitas yang asimetrik, serta mampu memperhitungkan karakteristik *long memory* dalam volatilitasnya sehingga menghasilkan pemodelan dan peramalan yang lebih baik.

Berdasarkan pemaparan di atas, ada beberapa motivasi dalam penelitian ini. Pertama, penelitian ini mengkaji pengembalian harga penutupan untuk menemukan memori yang panjang dan volatilitas asimetris. Kedua, dalam penelitian ini akan dikaji tentang model ARFIMA-FIAPARCH untuk meramalkan *return* harga saham PT. Bank Rakyat Indonesia. Dengan judul penelitian **“PENERAPAN MODEL ARFIMA-FIAPARCH UNTUK PERAMALAN HARGA SAHAM”**.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan di atas, maka rumusan masalah dalam penelitian ini adalah

1. Bagaimana model terbaik untuk meramalkan *return* harga saham PT. Bank Rakyat Indonesia dengan menggunakan model ARFIMA-FIAPARCH?
2. Bagaimana hasil peramalan dari model ARFIMA-FIAPARCH pada *return* harga saham PT. Bank Rakyat Indonesia untuk beberapa periode ke depan?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah di atas, maka tujuan dalam penelitian ini adalah

1. Menemukan model terbaik untuk meramalkan *return* harga saham PT. Bank Rakyat Indonesia menggunakan model ARFIMA-FIAPARCH.
2. Meramalkan *return* harga saham PT. Bank Rakyat Indonesia dengan menggunakan model ARFIMA-FIAPARCH untuk beberapa periode berikutnya.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian ini sebagai berikut:

1. Manfaat Teoritis

Manfaat teoritis dari penelitian ini yaitu dapat memberikan gambaran dan wawasan tentang penerapan model ARFIMA-FIAPARCH dalam meramalkan *return* harga saham PT. Bank Rakyat Indonesia.

2. Manfaat Praktis

Manfaat praktis dari penelitian ini yaitu dapat menjadi informasi sekaligus referensi untuk para investor dalam memperkirakan *return* harga saham PT. Bank Rakyat Indonesia berdasarkan peramalan dengan menggunakan model ARFIMA-FIAPARCH.

1.5 Batasan Masalah

Mengingat banyaknya metode peramalan yang dapat digunakan, maka masalah akan dibatasi pada:

1. Data yang digunakan dalam penelitian ini adalah data sekunder, yaitu nilai harian dari penutupan harga saham PT Bank Rakyat Indonesia Tbk. periode Januari 2017 hingga April 2020. Data tersebut diperoleh dari Bursa Efek Indonesia melalui situs *yahoo finance* www.duniainvestasi.com/bei. Untuk analisis, data yang digunakan adalah *return* harga saham.
2. Interval nilai ditentukan dengan taraf signifikansi 95%.
3. Software yang akan digunakan dalam penelitian ini yaitu:
 - 3.1 Ms. Excel digunakan untuk tabulasi data.

3.2 Perangkat lunak *Minitab 18* dan *OxMetrics 7.2*. digunakan untuk Analisis data *return* harga saham.

4. Model ARFIMA-FIAPARCH terbaik dalam penelitian ini didasarkan pada nilai AIC dan SC terkecil.